

自适应动模式分解和 GA-SVM 在行星轴承故障分类中的应用

蔡志鑫¹⁾, 党 章^{1)✉}, 吕 勇¹⁾, 袁 锐¹⁾, 安柄南²⁾

1) 武汉科技大学机械自动化学院, 武汉 430081 2) 南昌航空大学飞行器工程学院, 南昌 330000

✉通信作者, E-mail: dangzhang@wust.edu.cn

摘 要 行星齿轮箱在运行过程中由于齿轮间的相互作用会产生强噪声, 导致行星轴承的故障特征被完全淹没在背景噪声中并难以提取, 从而使得行星轴承故障分类的准确率较低。本文提出一种自适应动模式分解 (ADMD) 和遗传算法优化支持向量机 (GA-SVM) 的行星轴承故障分类方法。首先, 针对传统动模式分解 (DMD) 中截断秩无法准确选取的问题, 定义了一种新的适应度函数, 并采用改进的蚱蜢优化算法 (IGOA) 自适应选取最优截断秩, 进而实现对原始振动信号的降噪处理。然后对处理后的信号计算其归一化后的复合精细多尺度离散熵 (IRCMDE) 并构成特征矩阵。最后采用遗传算法优化支持向量机, 构建 GA-SVM 分类模型, 并将其应用到行星轴承故障诊断中。利用行星齿轮箱中行星轴承故障数据验证了此方法的有效性和实用性, 最终分类结果为 96.43%, 表明了该方法可以准确识别出行星轴承的故障类型。

关键词 动模式分解; 支持向量机; 蚱蜢优化算法; 精细复合多尺度离散熵; 行星轴承; 故障分类

分类号 TH113; TH133.33

Adaptive dynamic mode decomposition and GA-SVM with application to fault classification of planetary bearing

CAI Zhixin¹⁾, DANG Zhang^{1)✉}, LÜ Yong¹⁾, YUAN Rui¹⁾, AN Bingnan²⁾

1) School of Machinery and Automation, Wuhan University of Science and Technology, Wuhan 430081, China

2) School of Aircraft Engineering, Nanchang Hangkong University, Nanchang 330000, China

✉ Corresponding author, E-mail: dangzhang@wust.edu.cn

ABSTRACT Recently, planetary gearboxes have been widely used in helicopters, heavy trucks, ships, and other large and complex mechanical equipment because of their smooth transmission characteristics, small volume, and large reduction ratio. The planetary bearing, which plays a supporting role in the planetary gearbox, usually works in a worse environment but suffers from low speed and heavy load for a long time. Additionally, because of the strong noise generated by the interaction between gears during the operation of the planetary gearbox, the fault characteristics of planetary bearings are completely submerged in the background noise and are difficult to extract, which complicates classifying planetary-bearing faults accurately. Therefore, to effectively remove noise information from planetary-bearing signals, accurately extract fault information, and classify the fault types of planetary bearings, an adaptive dynamic mode decomposition (ADMD) and genetic algorithm and support vector machine (GA-SVM) with application to the fault classification of planetary bearing is proposed in this paper. The hard threshold selection of the traditional truncated rank cannot effectively process the time-domain vibration signals using the dynamic mode decomposition (DMD) method. Hence, this paper proposes improved grasshopper optimization algorithm (IGOA) to optimize the grasshopper optimization algorithm (GOA) by using dynamic weight and

收稿日期: 2022-07-01

基金项目: 国家自然科学基金资助面上项目 (51875416); 湖北省自然科学基金创新群体项目 (2020CFA033); 中国博士后科学基金资助面上项目 (2020M682492)

avoid the linear gradient mechanism, which cannot fully use the entire iterative process. Furthermore, IGOA can perform a global search to achieve the adaptive optimal parameter selection of the truncated rank. Besides, a new fitness function is defined that can effectively process the original time-domain signals. The traditional refined composite multiscale discrete entropy (RCMDE) is relatively dispersed, and it cannot characterize the features hidden in the signal better. Therefore, we normalize the RCMDE, forming the improved refined composite multiscale discrete entropy (IRCMDE). Then, the IRCMDE is calculated for the denoised signal, and a feature matrix is constructed to better mine the hidden features in the signal. Finally, GA is used to optimize the key parameters C and g of the SVM. The GA-SVM classification model is also constructed and applied to the bearing fault classification of the planetary gearbox, which can avoid the overfitting phenomenon in the training process and provide better generalization performance. Taking the planetary-bearing fault data in the planetary gearbox of Nanchang Hangkong University as the research object, the validity and practicability of the proposed method are verified, and the final classification result of the inner ring fault, outer ring fault, rolling body fault, and normal condition is 96.43%. In addition, this method can more accurately identify the fault types of planetary bearings and has better generalization ability than the empirical mode decomposition (EMD) signal processing method and the convolutional neural network (CNN) classification method.

KEY WORDS dynamic mode decomposition; support vector machine; grasshopper optimization algorithm; refined composite multiscale discrete entropy; planetary bearing; fault classification

行星齿轮箱具有传动平稳、体积小、减速比大等特点,近年来已在直升机、重型卡车、船舰等大型复杂机械设备中得到广泛应用^[1].行星轴承在行星齿轮箱中起支撑作用,其运行工况环境比较恶劣且长期受到低速重载的作用,往往会导致行星轴承出现各种故障,给工业生产以及人员安全带来严重威胁^[2].因此,对行星轴承故障诊断的研究将十分必要.

行星齿轮箱因自身结构特点以及工况影响,使行星轴承信号中所包含的特征信息被淹没在背景噪声中,这给行星轴承信号特征的有效提取带来严峻的挑战.针对信号处理,常用的方法主要有小波变换 (Wave transforms, WT)^[3]、经验模式分解 (Empirical mode decomposition, EMD)^[4] 以及变分模态分解 (Variational mode decomposition, VMD)^[5] 等.其中,WT的结果依赖小波基函数和分解层的选择和设定,对最终的结果影响较大,不具有自适应性,只能反应某一固定频带内的信号^[6].EMD没有严格的公式推导,可能会造成过估计模式的数量,并且EMD在对故障信号的分解过程中易产生模态混叠现象,对信号特征的提取产生不利影响^[7].VMD在处理过程中也会发生模态混叠现象,同时,VMD的分量数目需要人为确定^[8].

动模式分解 (Dynamic mode decomposition, DMD) 是一种基于降阶算法和模式分解理论的无方程 Koopman 频率分析技术,能够将复杂流场分解为一系列简单的低秩形式,从而精确提取动态系统的时空特征^[9-10].DMD结合了空间降维和本征正交分解的优点,可以将信号分解为一系列非正交

单一频率模式,其中每个模式对应于原始信号的低秩成分或稀疏成分^[11].同时,DMD对处理非线性非平稳信号具有优良的性能,可以有效的表征故障特征^[12].此外,还可以避免EMD和VMD中所存在的模态混叠问题,并且可以克服WT仅反映某一固定频带内信号的缺陷.

熵通常被用来描述一个系统或者分布的不确定性,熵值越大,系统越混乱,不确定性越大^[13].近年来,为了表征信号的复杂程度,信息熵理论不断发展,近似熵 (Approximate entropy, AE)^[14]、样本熵 (Sample entropy, SampEn)^[15] 和排列熵 (Permutation entropy, PE)^[16] 等非线性信号特征提取方面的应用研究中取得了一定的成就.但是,近似熵对于复杂度低的信号区分不明显^[17];样本熵计算慢,实时性差,且相似性度量易发生突变^[18];排列熵虽然概念简单计算速度快,但没有考虑振幅的平均值和振幅之间的差异^[19].2016年,Rostaghi和Azami^[20]提出了一种新的不规则衡量指标——离散熵.离散熵计算速度快且考虑了幅值间关系,在一定程度上解决了其他熵存在的缺陷.上述熵均是基于时间序列的单一尺度分析方法,为了进一步挖掘信号中隐藏的信息,Azami^[21]提出了精细复合多尺度离散熵 (Refined composite multi-scale discrete entropy, RCMDE),其多尺度过程稳定性好,特征提取效果优于其他多尺度方法.

针对滚动轴承的故障识别,主要的方法有决策树 (Decision tree, DT)^[22]、BP神经网络^[23]、支持向量机 (Support vector machine, SVM)^[24] 等.其中,DT原理简单、可解释性强,但其使用范围有限,泛化

能力较差,且受主观影响较大;BP神经网络对训练样本量的需求较大并在很大程度取决于特征提取的质量;SVM算法原理简单,有优秀的泛化能力,但SVM对分类效果参数的选择较为敏感。

基于上述分析,本文提出了一种自适应动模式分解(Adaptive dynamic mode decomposition, ADMD)和遗传算法优化支持向量机(GA-SVM)的行星轴承故障分类方法,通过改进蚱蜢优化算法(Improved grasshopper optimization algorithm, IGOA)自适应选取DMD的截断秩,对处理后的信号计算其归一化后的RCMDE值并构建特征矩阵。然后将特征矩阵输入到GA-SVM中实现行星轴承的故障分类。最后,采用行星齿轮箱行星故障轴承实测数据验证了该方法的有效性。

1 自适应动模式分解

1.1 动模式分解

DMD是一种将信号分解为动态模式的时空分解方法,是一种基于降阶算法和模式分解理论的无方程Koopman频率分析技术。DMD的主要思想为将传感器采集到的振动信号 S 在时域上分成两个连续的矩阵 X 和 Y 。其中, $S=[X_1, X_2, \dots, X_i, \dots, X_n]$, $X_i \in \mathbf{R}^{m \times 1}$, $S \in \mathbf{R}^{m \times n}$
 $X=[X_1 X_2 \dots X_{n-1}]$, $Y=[X_2 X_3 \dots X_n]$, $X, Y \in \mathbf{R}^{m \times (n-1)}$ (1)

寻找一个最优的局部线性逼近算子 A 实现从 X 到 Y 的映射。当数据呈现非线性时,比如轴承振动信号, A 可以近似表示其内在的动力学特征。

$$Y = AX \quad (2)$$

计算误差满足最小化 F 范数。

$$\bar{A} = \underset{A}{\operatorname{argmin}} \|Y - A \cdot X\|_F^2 \quad (3)$$

由此得到的 $\bar{A}$ 和 A 是相似矩阵。

DMD算法的关键步骤如下:

(1) 对矩阵 X 进行奇异值分解得到

$$X \approx U \Sigma V^* \quad (4)$$

式中,*表示共轭转置, U 、 V 表示分解得到的左右特征向量。其中, U 和 V 的列向量是正交的, $\Sigma_r \in \mathbf{R}^{r \times r}$ 包含 r 个非零特征值,成对角分布。

(2) 选取最佳截断秩 r ,将式(2)右乘(4)的逆,得到

$$A = YV_r \Sigma_r^{-1} U_r^* \quad (5)$$

由于 S 是高维数据,故 A 的数据量非常大,将其投影到 r 阶特征向量中,得到相似矩阵 $\bar{A}$ 。

$$\bar{A} = U_r^* A U_r = U_r^* Y V_r \Sigma_r^{-1} \quad (6)$$

式中 $\bar{A} \in \mathbf{R}^{r \times r}$ 。由于 $\bar{A}$ 是 A 的相似矩阵,因此 $\bar{A}$ 的特征向量和特征值与 A 的特征向量和特征值一致。

(3) 对 $\bar{A}$ 进行特征值分解

$$\bar{A} = W \Lambda W^{-1} \quad (7)$$

式中, $W=[\omega_1, \omega_2, \dots, \omega_r] \in \mathbf{R}^{r \times r}$ 为 $\bar{A}$ 的特征向量, $\Lambda = \operatorname{diag}([\lambda_1, \lambda_2, \dots, \lambda_r]) \in \mathbf{R}^{r \times r}$ 为对角阵。

(4) 计算动模式

得到 $\bar{A}$ 后就可以得到信号的演变特征,则原始算子 A 的第 i 阶特征向量可由 $\bar{A}$ 的特征向量近似代替。

$$\phi_i = YV_i \Sigma_i^{-1} W_i \quad (8)$$

式(8)一般被称为精确动模式分解,它由特征值和特征向量的低秩矩阵逼近得到。动模式分解的重构矩阵通过 r 阶特征向量求和得到。

$$X_{\text{DMD}} = \sum_{i=1}^r \phi_i \exp(\lambda_i \Delta t) b_i = \Phi \exp(\Omega t) b \quad (9)$$

式中, Δt 表示采样时间间隔; t 是采样时间; Φ 是动模式分解的特征向量 ϕ_i 组成的矩阵; $\Omega = \operatorname{diag}(\lambda_j)$ 是 $\bar{A}$ 的特征值 λ_j 组成的对角阵; $b = \Phi^T X_1$ 表示所有模式的幅值,其中 T 表示广义逆。

由于DMD的分解效果很大程度依赖截断秩的选取,而传统硬阈值的截断秩选取方式主要依赖人为选取,并且达不到最佳效果。对此,本文提出采用IGOA实现DMD截断秩的自适应选取。

1.2 改进的蚱蜢优化算法

蚱蜢优化算法(Grasshopper optimization algorithm, GOA)算法的灵感来自于蚱蜢的觅食行为^[25]。蚱蜢的生活史分为幼虫期和成虫期两大阶段。幼虫期蚱蜢的显著特征是移动缓慢,而更大的和随意的移动是成年期蚱蜢至关重要的属性^[26]。在数学上,蚱蜢的群集行为模型为

$$X_i = S_i + G_i + A_i \quad (10)$$

式中, X_i 表示第 i 只蚱蜢的位置, S_i 表示蚱蜢之间的相互作用, G_i 表示第 i 只蚱蜢的重力, A_i 表示所受风力的影响。

式(10)中 S_i 的表达式为

$$S_i = \sum_{j=1, j \neq i}^N s(w_{ij}) \widehat{w}_{ij} \quad (11)$$

式中, $w_{ij} = |x_j - x_i|$ 是第 i 个和第 j 个蚱蜢之间的距离, $\widehat{w}_{ij}$ 表示第 i 个和第 j 个蚱蜢之间的单位向量, s 表示蝗虫的相互影响力,计算式为

$$s(w) = f e^{\frac{w}{l}} - e^{-w} \quad (12)$$

式中, f 为吸引力常数, l 为吸引长度尺度。

式(10)中 G_i 的表达式为

$$G_i = -\rho \widehat{e}_\rho \quad (13)$$

式中, ρ 代表引力常数, $\widehat{e}_\rho$ 为指向地心的单位矢量.

A_i 的计算公式为

$$A_i = \varepsilon \widehat{e}_w \quad (14)$$

式中, ε 表示漂移常数, $\widehat{e}_w$ 为风向的单位矢量.

将 S_i , G_i 和 A_i 的表达式代入式 (10), 可以得到

$$X_i = c_1 \left(\sum_{j=1, j \neq i}^N c_2 \frac{\text{ub} - \text{lb}}{2} s(|x_j - x_i|) \frac{x_j - x_i}{d_{ij}} \right) + \widehat{T} \quad (15)$$

式中, 上限和下限分别用 ub 和 lb 表示; $\widehat{T}$ 为目标值, 即最佳解; c_1 用来平衡全局和局部寻优能力; c_2 为舒适区、排斥区和吸引区的收缩系数. c_1 和 c_2 被认为是单个参数, 用式 (16) 表示.

$$c = c_{\max} - I \frac{c_{\max} - c_{\min}}{N} \quad (16)$$

式中, I 表示当前迭代的次数, N 表示最大迭代次数, $c_{\max}$ 和 $c_{\min}$ 分别表示最大值和最小值.

传统线性递减的参数机制并不能使算法充分利用整个迭代过程. 为了提高算法利用率, IGOA 算法中引入了动态权重参数机制, 改进后的算法在搜索过程分为 3 个阶段, 即前期、中期和后期. 在早期阶段, 目标位置的权重高, 使搜索过程可以快速收敛; 在中间阶段, 参数保持稳定, 在整个空间内进行搜索; 在后期阶段, 为了深入挖掘局部最优解的位置, 采用更小的权重参数^[27]. 动态权重参数机制的迭代方程为:

$$X_i = mc \left(\sum_{j=1, j \neq i}^N c \frac{\text{ub} - \text{lb}}{2} s(|x_j - x_i|) \frac{x_j - x_i}{d_{ij}} \right) + \widehat{T} \quad (17)$$

式中, m 为调整搜索过程的动态权重参数. 根据搜索过程中 3 个阶段的特征, 参数 m 的计算为:

$$m = \begin{cases} 0.5 - \frac{(0.5 - 0.1) \times \text{iter}}{0.2 \times \text{MaxIteration}}, & 0 < \text{iter} \leq 0.2 \times \text{MaxIteration} \\ 0.1, 0.2 \times \text{MaxIteration} < \text{iter} \leq 0.8 \times \text{MaxIteration} \\ 0.05, 0.8 \times \text{MaxIteration} < \text{iter} \end{cases} \quad (18)$$

1.3 适应度函数

在使用 IGOA 算法时, 需要定义一个适应度函数来衡量所优化参数的质量, 根据目标函数的大小来确定最优参数.

当轴承发生局部故障时, 时域中会出现一个周期性的脉冲信号, 其频谱中会包含有故障频率及其倍频^[28]. 因此, 特征能量可以用来衡量周期性冲击. 同时, 特征频率的能量值相对大于其他噪声成分的能量值, 且为保证每一次分解后的能量值不会损失太多, 故采用特征能量差来更好的表示

分解效果.

当时域中存在一个周期性脉冲分量时, 包络谱中会出现明显的故障频率及其倍频^[29]. 合成峭度是由包络谱幅值峭度和峭度构成的新指标. 其中, 峭度是一种评价故障冲击性能的指标, 对冲击信号较为敏感, 但忽略了循环平稳性^[30]. 包络谱幅值峭度可以用来描述故障冲击的循环平稳性^[31]. 二者的结合可以弥补峭度指标不能用来描述周期平稳性的局限性^[32], 即

$$\text{ESK} = \frac{\sum_{j=1}^p |\overline{\text{SE}(j)}|^4}{\left(\sum_{j=1}^p |\overline{\text{SE}(j)}|^2 \right)^2} \quad (19)$$

$$\text{EK} = \text{ESK} \cdot \text{ku} \quad (20)$$

式中, ku 、 EK 、 ESK 分别表示峭度、合成峭度、包络谱幅值峭度. SE 为信号的包络谱; p 表示包络谱的采样点数. 其中, 当分解结果中的周期性冲击明显时, 合成峭度值较大, 不明显时合成峭度值较小.

因此, 本文定义了一个合成包络峭度特征能量差值比作为自适应指数, 即

$$\text{Function} = \frac{\text{EDV}}{\text{EK} \cdot E} \quad (21)$$

式中, Function 表示适应度函数, EDV 表示特征能量差, EK 表示合成峭度, E 表示特征能量. 当分解结果中的周期冲击不明显时, Function 值较大; 当分解结果中的周期冲击明显时, Function 值较小. 因此, 本文可以实现通过监测 Function 的变化来反应信号分解结果的好坏, 当 Function 达到最小值时, 分解结果最优. 从而利用 IGOA 算法实现 DMD 截断秩的自适应最优选取, 得到信号的最佳分解.

1.4 改进的精细复合多尺度离散熵

RCMDE 是在 MDE 的基础上改进而来的. MDE 是对序列进行不同尺度的粗粒化, 然后计算其离散熵值. 而 RCMDE 是先计算每个粗粒化序列离散模式的概率, 再求这些离散模式概率的平均值, 最后根据公式计算 RCMDE. RCMDE 的计算步骤为:

(1) 对于原始数据 $u = \{u_1, u_2, \dots, u_L\}$, L 为信号长度. 在 RCMDE 算法中, 原信号 u 从 u_1 开始被平均分成 τ 小段, 先求出每小段的平均值, 再将每小段的平均值组成粗粒化序列. 其中, 第 k 个粗粒化序列如式 (22) 所示.

$$x_{k,j}^\tau = \frac{1}{\tau} \sum_{b=k+\tau(j-1)}^{k+j\tau-1} u_b, \quad 1 \leq j \leq \frac{L}{\tau}, \quad 1 \leq k \leq \tau \quad (22)$$

(2) 计算每个粗粒化离散模式 θ 的概率, 然后求出所有离散模式概率的平均值。

① 利用正态分布函数公式将 $x_{k,j} = \{x_j, j = 1, 2, \dots, N\}$ 映射到 $y = \{y_j, j = 1, 2, \dots, N\}$, 其中 $y_j \in (0, 1)$, y_j 的计算公式为:

$$y_j = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^{x_j} e^{-(t-\mu)^2/(2\sigma^2)} dt \quad (23)$$

式中, μ 和 σ 分别表示均值和标准差。

② 通过线性算法将 y_j 映射到 $[1, 2, \dots, c]$ 的范围内, 即:

$$z_j^b = R(b \cdot y_j + 0.5) \quad (24)$$

式中, z_j^b 表示时间序列的类数, $R(*)$ 是取整运算, b 代表类别个数。

③ 计算嵌入维数 m 和时间延迟组成的嵌入向量序列 $z_i^{m,b}$ 。

$$z_i^{m,b} = \{z_i^b, z_{i+d}^b, \dots, z_{i+(m-1)d}^b\} \quad (25)$$

④ 计算离散模式 $\theta_{v_0 v_1, \dots, v_{m-1}} (m-1 = 1, 2, \dots, c)$ 。若 $z_i^b = v_0, z_{i+d}^b = v_1, \dots, z_{i+(m-1)d}^b = v_{m-1}$, 则 $z_i^{m,b}$ 对应的离散模式为 $\theta_{v_0 v_1, \dots, v_{m-1}}$ 。

⑤ 计算每种离散模式 $\theta_{v_0 v_1, \dots, v_{m-1}}$ 的概率 $P(\theta_{v_0 v_1, \dots, v_{m-1}})$:

$$P(\theta_{v_0 v_1, \dots, v_{m-1}}) = \frac{\text{num}(\theta_{v_0 v_1, \dots, v_{m-1}})}{N - (M-1)d} \quad (26)$$

式中, $\text{num}(\theta_{v_0 v_1, \dots, v_{m-1}})$ 表示 $z_i^{m,b}$ 映射到 $\theta_{v_0 v_1, \dots, v_{m-1}}$ 的个数。

(3) 对于每个尺度下的 τ , RCMDE 定义为:

$$\begin{aligned} \text{RCMDE}(X, m, b, d, \tau) = \\ - \sum_{n=1}^c \bar{P}(\theta_{v_0 v_1, \dots, v_{m-1}}) \ln [\bar{P}(\theta_{v_0 v_1, \dots, v_{m-1}})] \end{aligned} \quad (27)$$

式中, $\bar{P}(\theta_{v_0 v_1, \dots, v_{m-1}}) = \frac{1}{\tau} \sum_{k=1}^{\tau} P_k^{\tau}$ 为粗粒化序列 x_k^{τ} 的离散模式概率的平均值。

由于最终得到的 RCMDE 值较为分散, 不利于表征隐藏在信号中的特征, 因此, 我们提出 IRCMDE, 将 RCMDE 值做进一步归一化处理。

$$\text{IRCMDE} = \frac{\text{RCMDE} - \text{RCMDE}_{\min}}{\text{RCMDE}_{\max} - \text{RCMDE}_{\min}} \quad (28)$$

式中, IRCMDE 表示归一化后的熵值, $\text{RCMDE}_{\min}$ 和 $\text{RCMDE}_{\max}$ 分别表示 RCMDE 的最小值和最大值。

2 行星齿轮箱轴承故障分类算法

2.1 遗传算法优化的支持向量机

SVM 是用于求解能够正确划分训练数据集并且几何间隔最大的分离超平面的一种算法。SVM

常采用高斯径向基核函数 $K(x, x_i) = \exp(-g\|x - x_i\|^2)$, 其中 g 为控制核函数尺度的参数^[33]。则 SVM 可以转换成求解最优化问题:

$$\min_a \frac{1}{2} \sum_{i=1}^j \sum_{j=1}^l y_i y_j a_i a_j K(x_i, x_j) - \sum_{j=1}^l a_j \quad (29)$$

$$s.t. \sum_{i=1}^l y_i a_i = 0, \quad 0 \leq a_i \leq C \quad (30)$$

式中, $\{(x_i, y_i)\}$ 为训练集; $x_i, x_j \in \mathbf{R}^n$; $y_i, y_j \in \{-1, 1\}$; a_i, a_j 为拉格朗日算子; $i, j = 1, 2, \dots, l$, C 为惩罚参数, $s.t.$ 表示约束条件。

由于 SVM 分类的准确率与精度主要受惩罚参数 C 和控制核函数尺度参数 g 取值的影响, 而传统 SVM 主要靠经验来得到最佳参数, 不具有普及性。

遗传算法 (Genetic algorithm, GA) 算法是一种比较常用的搜索算法, 以自然选择和群体遗传作为其内在核心机理, 模拟自然界中广泛存在的“适者生存”现象, 包括繁殖、杂交以及突变等情况。作为一种高效、并行、全局的搜索方法, GA 算法可以在搜索过程中自适应的获得最佳解, 被广泛应用于优化问题的求解^[34-35]。因此, 本文采用 GA 算法来寻找 SVM 的最佳参数 C 和 g 。GA-SVM 算法的技术路线如图 1 所示。




图1 GA-SVM 技术框架

Fig.1 GA-SVM technology framework

2.2 ADMD 和 GA-SVM 的行星轴承故障分类算法

ADMD 和 GA-SVM 的行星轴承故障分类算法是基于行星轴承信号的振动特性, 结合 ADMD 和 GA-SVM 两种方法的优点实现的. 由于行星齿轮箱自身的复杂结构和行星轴承独特的工作条件导致行星轴承在转动过程中会出现明显的调制现象, 使得行星轴承信号中包含了大量的噪声信号. DMD 是一种基于降阶算法和模式分解理论的无方程 Koopman 频率分析技术, 能够精确提取原始信号中所包含的动力学特征. 但是由于行星轴承所处的环境较为恶劣, 噪声嘈杂, 对所采集信号的处理分析造成很大的干扰, 使得其无法准确选取截断秩, 不能有效去除环境噪声所带来的影响, 因此采用 ADMD 方法将原始信号分解为以特征信息为主的低秩成分和以背景噪声为主的稀疏成分, 去掉稀疏成分则可以有效的减少噪声的影响.

GOA 是一种用于全局优化的新型元启发式算法, 主要应用于参数的最优化选取方面, 但是它在参数优化过程中容易陷入局部最优, 从而影响参数的选取. 针对这种情况, 采用动态权重来改进传统 GOA 算法, 从而使结果跳出局部搜索, 最终实现全局搜索的目的. 同时本文定义了一个合成包络峭度特征能量差值比作为目标函数, 以更好的实现参数最优化选取.

RCMDE 的多尺度过程稳定性好, 特征提取效果优于其他多尺度熵, 同时可以进一步挖掘信号中的隐藏特征. 但是, RCMDE 熵值较为分散, 本文提出对计算得到的 RCMDE 做进一步的归一化处理, 可以更好的表征信号特征.

SVM 具有优异的泛化性能, 但其分类效果的好坏很大程度上取决于参数的选取. 而采用 GA-SVM 算法可以避免因人为经验不足导致分类结果不理想的情况的出现.

基于上述分析, 本文提出了一种 ADMD 和 GA-SVM 的行星轴承故障分类算法用于对不同故障行星轴承信号的分类. 其技术路线如图 2 所示.

3 实验结果与分析

通过对行星齿轮箱中行星轴承故障振动信号进行分析, 验证算法的有效性. 将采集到的故障振动信号首先经过 ADMD 处理, 然后对处理后的信号计算其归一化后的 RCMDE 值并将其构成特征矩阵, 再通过 GA-SVM 进行分类. 为了进一步测试所提算法的性能, 本文进行了比较研究.




图 2 ADMD 和 GA-SVM 的行星轴承故障分类方法技术路线
Fig.2 Schematic of the ADMD and GA-SVM

3.1 实验装置

所用实验装置如图 3 所示. 行星齿轮箱如图 4(a) 所示, 其中采集振动信号用的加速度传感器 PCB 604B31 三轴加速度传感器安装在行星齿轮箱上, 如图 4(b) 所示. 本文测量了 4 种不同状态下的行星轴承振动信号, 分别为内圈故障、外圈故障、滚动体故障和无故障. 行星齿轮箱的主要参数见表 1.




图 3 实验装置
Fig.3 Experimental equipment




图 4 行星齿轮箱传感器布置图. (a) 行星齿轮箱; (b) 传感器位置
Fig.4 Planetary gear box sensor layout: (a) planetary gear box; (b) sensor location

3.2 故障分类

振动信号的采样频率为 20 kHz, 采样时间为 32 s, 采样点数为 655360 个, 各类故障信号如图 5

表1 行星齿轮箱的主要参数

Table 1 Main parameters of planetary gear box

Number of teeth of sun wheel	Number of planetary gear teeth	Ring gear
28	36 (3)	100




图5 不同故障模式下振动信号时域图。(a) 内圈信号；(b) 外圈信号；(c) 滚动体信号；(d) 正常信号

Fig.5 Time-domain diagrams of vibration signals under different fault modes: (a) inner ring signal; (b) outer ring signal; (c) rolling body signal; (d) normal signal

3.3 分类结果与比较分析

将处理后的特征矩阵输入到 GA-SVM 模型中,按照 8 : 2 的比例自动化分训练集和测试集,即训练集共 224 组,测试集共 56 组。根据实际调试过程,最终遗传算法的参数设定为:群体大小为 20、交叉概率为 0.9、变异概率为 0.8、遗传算法的终止进化代数为 200。模型经过 200 次迭代后,可以得到 GA-SVM 参数的适度曲线,如图 6 所示,同时可以得到 SVM 的最优参数。其中,惩罚因子 $C=589.17$,核函数尺度控制参数 $g=0.16$ 。

将 ADMD+GA-SVM 行星轴承故障分类方法与 ADMD+CNN 方法和 EMD+GA-SVM 方法进行对比,验证其有效性。用相同的数据进行实验,分类结果及准确率分别如图 7 和表 2 所示。

从图 7 和表 2 中可以看出,采用 ADMD 和 GA-SVM 法对行星轴承 4 种故障的识别准确率为 96.43%,可

所示。首先对不同故障信号分别取 70 组进行 ADMD 处理,其中,IGOA 的参数设置如下:蚱蜢种群数为 30,最大迭代数为 10, $c_{\max}=1$, $c_{\min}=0.0001$ 。对处理后的信号计算其 IRCMDE 值并形成相应的特征矩阵。

以准确识别出不同故障类型的行星轴承;而 ADMD+CNN 方法进行处理后的故障分类准确率只有 78.57%, EMD+GA-SVM 方法的准确率有 91.07%。这可能是由于 CNN 模型的训练对数据量要求较高,因此




图6 GA-SVM 参数的适应度曲线

Fig.6 Fitness curve of GA-SVM parameters




图 7 不同方法分类结果. (a) ADMD+GA-SVM 法; (b) ADMD+CNN 法; (c) EMD+GA-SVM 法

Fig.7 Classification results by different methods: (a) ADMD+GA-SVM method; (b) ADMD+CNN method; (c) EMD+GA-SVM method

表 2 不同方法对行星齿轮箱行星轴承分类结果

Table 2 Classification results of planetary bearings in planetary gearboxes by different methods

Methods	Accuracy /%
ADMD+GA-SVM	96.43
ADMD+CNN	78.57
EMD+GA-SVM	91.07

使用 ADMD+CNN 方法对行星轴承故障进行分类时, 各类故障分类结果中均存在明显的分类错误现象, 分类效果并不理想. 而 EMD+GA-SVM 虽然对滚动体故障有较好的分类效果, 但是对内圈等其他故障的分类中仍存在不足. 因此, 通过 ADMD+GA-SVM 方法与传统 CNN 模型及其他算法的比较, 表明了采用本文方法的分类结果优于其他方法, 验证了其有效性和实用性, 实现了对行星轴承故障的有效分类, 具有更好的泛化能力.

4 结论

行星齿轮箱在齿轮啮合时产生大量的噪声使得行星轴承故障信息往往会被完全淹没难以提

取, 从而行星轴承故障分类难以得到较高的分类准确率. 因此本文提出一种 ADMD 和 GA-SVM 的行星轴承故障分类算法来有效去除行星轴承信号中的噪声信息, 准确提取故障信息, 实现对行星轴承故障类型的准确分类. 首先采用 IGOA 算法自适应选择 DMD 的截断秩, 然后对故障信号进行分解, 将分解后的信号计算 IRCMDE 值并构建特征矩阵, 最后采用 GA-SVM 模型进行分类准确率为 96.43%, 但是还有一定的提升空间. 因此, 提高行星轴承故障分类准确率将是下一阶段的工作重点. 主要贡献为:

- (1) 定义了新的适应度函数, 采用优化后的目标参数可以实现更好的分解效果.
- (2) 采用动态权重优化传统 GOA 算法, 跳出局部搜索, 自适应选择 DMD 的截断秩, 获得更好的分解效果, 准确提取故障特征.
- (3) 采用 IRCMDE 值作为特征, 稳定性好, 同时可以更好的挖掘信号隐藏的特征信息.
- (4) 采用 GA 算法优化的 SVM, 可以避免训练过程出现过拟合现象, 具有更好的泛化性能.

参 考 文 献

- [1] Lei Y G. Adaptive ensemble empirical mode decomposition and its application to fault detection of planetary gearboxes. *J Mech Eng*, 2014, 50(3): 64
- [2] Wang T Y, Chu F L, Feng Z P. Meshing frequency modulation (MFM) index-based kurtogram for planet bearing fault detection. *J Sound Vib*, 2018, 432: 437
- [3] Wang P, Li T Y, Gao X J, et al. Bearing fault signal denoising method of hierarchical adaptive wavelet threshold function. *J Vib Eng*, 2019, 32(3): 548
(王普, 李天垚, 高学金, 等. 分层自适应小波阈值轴承故障信号降噪方法. 振动工程学报, 2019, 32(3): 548)
- [4] Zhao X M, Patel T H, Zuo M J. Multivariate EMD and full spectrum based condition monitoring for rotating machinery. *Mech Syst Signal Process*, 2012, 27: 712
- [5] Wang Z Y, Yao L G, Qi X L, et al. Fault diagnosis of planetary gearbox based on parameter optimized VMD and multi-domain manifold learning. *J Vib Shock*, 2021, 40(1): 110
(王振亚, 姚立纲, 戚晓利, 等. 参数优化变分模态分解与多域流形学习的行星齿轮箱故障诊断. 振动与冲击, 2021, 40(1): 110)
- [6] Zheng X W, Tang Y Y, Zhou J T. A framework of adaptive multiscale wavelet decomposition for signals on undirected graphs. *IEEE Trans Signal Process*, 2019, 67(7): 1696
- [7] Lv Y, Yuan R, Wang T, et al. Health degradation monitoring and early fault diagnosis of a rolling bearing based on CEEMDAN and improved MMSE. *Materials*, 2018, 11(6): 1009
- [8] Zheng Y, Yue J H, Jiao J, et al. Fault feature extraction method of rolling bearing based on parameter optimized VMD. *J Vib Shock*, 2021, 40(1): 86
(郑义, 岳建海, 焦静, 等. 基于参数优化变分模态分解的滚动轴承故障特征提取方法. 振动与冲击, 2021, 40(1): 86)
- [9] Dang Z, Lv Y, Li Y R, et al. A fault diagnosis method for one-dimensional vibration signal based on multiresolution tIsDMD and approximate entropy. *Shock Vib*, 2019, 2019: 1
- [10] Rowley C W, Mezić I, Bagheri S, et al. Spectral analysis of nonlinear flows. *J Fluid Mech*, 2009, 641: 115
- [11] Taira K, Brunton S L, Dawson S T M, et al. Modal analysis of fluid flows: An overview. *AIAA J*, 2017, 55(12): 4013
- [12] Schmid P J, Li L, Juniper M P, et al. Applications of the dynamic mode decomposition. *Theor Comput Fluid Dyn*, 2011, 25(1): 249
- [13] Dou D, Ye X D, Zhang G H. Entropy sequences and maximal entropy sets. *Nonlinearity*, 2006, 19(1): 53
- [14] Pincus S M. Approximate entropy as a measure of system complexity. *Proc Natl Acad Sci*, 1991, 88(6): 2297
- [15] Shi Y, Lin J H, Zhuang Z, et al. Fault diagnosis for pantograph cracks based on time-frequency decomposition and sample entropy of vibration signals. *J Vib Shock*, 2019, 38(8): 180
(施莹, 林建辉, 庄哲, 等. 基于振动信号时频分解-样本熵的受电弓裂纹故障诊断. 振动与冲击, 2019, 38(8): 180)
- [16] Dang Z, Lv Y, Li Y R, et al. Optimized dynamic mode decomposition via non-convex regularization and multiscale permutation entropy. *Entropy*, 2018, 20(3): 152
- [17] Lin L, Zhao D Y. Application of approximate entropy in acoustic emission signal processing. *J Vib Shock*, 2008, 27(2): 99
(林丽, 赵德有. 近似熵在声发射信号处理中的应用. 振动与冲击, 2008, 27(2): 99)
- [18] Jiang Y, Mao D, Xu Y S. A fast algorithm for computing sample entropy. *Adv Adapt Data Anal*, 2011, 3(1-2): 167
- [19] Azami H, Escudero J. Amplitude-aware permutation entropy: Illustration in spike detection and signal segmentation. *Comput Methods Programs Biomed*, 2016, 128: 40
- [20] Rostaghi M, Azami H. Dispersion entropy: A measure for time-series analysis. *IEEE Signal Process Lett*, 2016, 23(5): 610
- [21] Azami H, Rostaghi M, Abásolo D, et al. Refined composite multiscale dispersion entropy and its application to biomedical signals. *IEEE Trans Biomed Eng*, 2017, 64(12): 2872
- [22] Achlerkar P D, Samantaray S R, Sabarimalai Manikandan M. Variational mode decomposition and decision tree based detection and classification of power quality disturbances in grid-connected distributed generation system. *IEEE Trans Smart Grid*, 2018, 9(4): 3122
- [23] Zhang S Q, Huang W J, Hu Y T, et al. Bearing fault diagnosis method based on EEMD approximate entropy and hybrid PSO-BP algorithm. *China Mech Eng*, 2016, 27(22): 3048
(张淑清, 黄文静, 胡永涛, 等. 基于总体平均经验模式分解近似熵和混合 PSO-BP 算法的轴承故障诊断方法. 中国机械工程, 2016, 27(22): 3048)
- [24] Abdoos A A, Mianaei P K, Ghadikolaei M R. Combined VMD-SVM based feature selection method for classification of power quality events. *Appl Soft Comput*, 2016, 38(C): 637
- [25] Saremi S, Mirjalili S, Lewis A. Grasshopper optimisation algorithm: Theory and application. *Adv Eng Softw*, 2017, 105: 30
- [26] Meraihi Y, Benmessaoud Gabis A, Mirjalili S, et al. Grasshopper optimization algorithm: Theory, variants, and applications. *IEEE Access*, 2021, 9: 50001
- [27] Zhao R, Ni H, Feng H W, et al. A dynamic weight grasshopper optimization algorithm with random jumping // *Advances in Intelligent Systems and Computing*. Singapore: Springer Singapore, 2019: 401
- [28] Yu J B, Hu T Z, Liu H Q. A new morphological filter for fault feature extraction of vibration signals. *IEEE Access*, 2019, 7: 53743
- [29] Ma Y B, Lv Y, Yuan R, et al. Matching synchroextracting transform for mechanical fault diagnosis under variable-speed conditions. *IEEE Trans Instrum Meas*, 2022, 71: 1

- [30] Wang D. Some further thoughts about spectral kurtosis, spectral $L2/L1$ norm, spectral smoothness index and spectral Gini index for characterizing repetitive transients. *Mech Syst Signal Process*, 2018, 108: 360
- [31] Ren Y, Li W, Zhang B, et al. Fault diagnosis of rolling bearings based on improved kurtogram in varying speed conditions. *Appl Sci*, 2019, 9(6): 1157
- [32] Zhang S, Zhang Y X, Zhu J P. Rolling element-bearing feature extraction based on combined wavelets and quantum-behaved particle swarm optimization. *J Mech Sci Technol*, 2015, 29(2): 605
- [33] Tang X B, Wang Z Q, Zhong L X. Microblog topic tracking model based on wikipedia semantic extension. *Inf Sci*, 2017, 35(2): 80 (唐晓波, 王中勤, 钟林霞. 基于维基语义扩展的微博话题追踪模型研究. 情报科学, 2017, 35(2): 80)
- [34] Zhang Y, Wu L H, Fan X M, et al. Identification and classification of power quality disturbances based on modified S transform and GA-SVM. *Guangdong Electr Power*, 2021, 34(5): 99 (张殷, 武利会, 范心明, 等. 基于改进S变换和GA-SVM的电能质量扰动识别与分类. 广东电力, 2021, 34(5): 99)
- [35] Xu Y, Song W X, Feng J Y, et al. Minimum pulse width modulation of current harmonic for three-level inverter. *J Shanghai Univ Nat Sci Ed*, 2017, 23(5): 690 (徐渊, 宋文祥, 冯九一, 等. 三电平逆变器电流谐波最小PWM方法. 上海大学学报(自然科学版), 2017, 23(5): 690)